

风电机组齿轮箱故障诊断与剩余寿命预测

——基于振动信号与深度学习

张晓伟

华电新能源集团股份有限公司山西分公司，山西 太原 030027

DOI:10.61369/WCEST.2025110021

摘 要： 为实现对风电机组齿轮箱故障的精准诊断与剩余寿命的可靠预测，本文提出了一种基于振动信号与深度学习的综合解决方案。在故障诊断方面，构建了包含数据采集、信号预处理、自适应特征提取、故障分类及性能评估的闭环模型。在剩余寿命预测方面，建立了“健康指标构建—退化轨迹建模—RUL预测”的预测框架。为打破诊断与预测任务间的壁垒，进一步基于多任务学习设计了融合框架，通过共享特征提取层与联合训练策略，实现了故障诊断与剩余寿命预测的协同优化。

关 键 词： 风电机组；齿轮箱；故障诊断；剩余寿命预测

Fault Diagnosis and Remaining Useful Life Prediction of Wind Turbine Gearboxes — Based on Vibration Signals and Deep Learning

Zhang Xiaowei

Shanxi Branch of Huadian New Energy Group Co., Ltd., Taiyuan, Shanxi 030027

Abstract： To achieve accurate fault diagnosis and reliable remaining useful life (RUL) prediction for wind turbine gearboxes, this paper proposes a comprehensive solution based on vibration signals and deep learning. In terms of fault diagnosis, a closed-loop model encompassing data acquisition, signal preprocessing, adaptive feature extraction, fault classification, and performance evaluation is constructed. For RUL prediction, a predictive framework is established, following the sequence of "health indicator construction—degradation trajectory modeling—RUL prediction." To bridge the gap between diagnosis and prediction tasks, a fusion framework is further designed based on multi-task learning, enabling collaborative optimization of fault diagnosis and RUL prediction through shared feature extraction layers and joint training strategies.

Keywords： wind turbine; gearbox; fault diagnosis; remaining useful life prediction

引言

传统的齿轮箱故障诊断方法主要依赖于傅里叶变换、小波分析等信号处理技术提取故障特征，再结合支持向量机（SVM）、人工神经网络等浅层模型进行分类。近年来以卷积神经网络、长短期记忆网络、Transformer等为代表的深度学习技术，凭借其强大的深层特征自动提取与非线性关系建模能力，为解决齿轮箱故障诊断提供了全新范式。鉴于此，本文旨在构建一个基于振动信号与深度学习的风电机组齿轮箱故障诊断与剩余寿命预测一体化框架。创新性地引入多任务学习思想，构建故障诊断与剩余寿命预测的融合模型，通过共享特征提取与联合训练策略，实现二者的协同增效。

一、基于振动信号与深度学习的齿轮箱故障诊断模型

（一）总体框架设计

风电机组的发电原理是将风的动能由风轮转化为机械能，再将机械能由发电机转化为电能，齿轮箱将风轮的低转速增至发电机所需的高转速，如果没有齿轮箱，将需要200极磁极发电机。齿轮箱是传动链中最重要的部件，其设计及制造非常关键，要求

体积小，重量轻，性能优良^[1]。基于振动信号与深度学习的齿轮箱故障诊断模型总体框架，含数据采集、信号预处理、自适应特征提取、故障状态分类及模型性能评估五大核心模块，形成“数据输入—信号处理—特征提取—状态识别—性能评估”完整闭环。数据采集模块获取不同运行状态的振动信号；预处理模块消除干扰，提供高质量数据；自适应特征提取模块借助深度学习自动提取深层故障特征，替代人工特征工程；分类模块输出故障类

型与程度；评估模块化模型诊断精度、泛化能力，为优化提供依据。该框架核心优势在于利用深度学习自适应提取特征，规避人工设计局限，且模块化设计便于后续优化与扩展。

（二）振动信号数据预处理

原始振动信号含多种干扰，直接训练会影响特征提取与诊断精度，振动信号预处理是齿轮箱故障诊断的关键前置步骤，核心包含四大环节^[2]。噪声去除环节采用小波阈值降噪与 EMD 结合，前者通过小波分解和高频系数阈值处理抑制噪声，后者分解信号为 IMF 分量并筛选重构消除非平稳噪声，提升信噪比；去趋势处理化解用最小二乘法或滑动平均法拟合并剔除线性 / 非线性趋势成分，获取平稳信号；数据分段与重采样环节按 1024–4096 点重叠分段提升数据利用率，用线性 / 三次样条插值统一不同工况信号的采样频率；数据标准化与增强环节通过 Z-score 或 min-max 标标准化统一信号幅值区间，借助添加高斯白噪声等方式扩充样本，缓解样本不平衡并提升模型泛化能力。

（三）基于深度学习的自适应特征提取

传统故障特征提取依赖人工经验与信号处理技术设计参数，存在主观性强、复杂故障适应性差的问题^[3]。基于深度学习的自适应方法可自动提取振动信号深层故障特征，效率与精度更高^[4]。本文采用 CNN-LSTM 混合模型，CNN 通过卷积、池化层捕捉齿轮磨损等局部故障特征，LSTM 则建模故障特征时序演变规律^[5]。预处理后的一维振动信号先转为二维形式输入 CNN，经其提取局部特征得到高维向量；该向量再输入 LSTM，结合层归一化与 dropout 技术解决梯度问题以挖掘时序规律。二者协同实现局部与时序特征的全面提取，为后续故障分类提供高质量支撑。

（四）故障状态分类模型构建

故障状态分类模型以自适应特征提取模块输出的深层特征向量为输入，输出齿轮箱正常状态、多种故障类型（齿轮、轴承、轴系等）及不同故障程度（轻度至重度磨损）^[6]。采用 Softmax 与 SVM 结合的分类策略提升精度与鲁棒性，将 LSTM 时序特征经带 dropout 正则化的全连接层转换为适配分类的低维特征，再分别输入两分类器（Softmax 适用于多类别场景，SVM 擅于小样本精准划分），通过加权投票融合结果。另采用交叉验证（网格 / 随机搜索）优化 CNN、LSTM、全连接层等超参数，保障模型分类精度与泛化能力。

二、基于深度学习的齿轮箱剩余寿命预测模型

（一）总体框架设计

基于深度学习的齿轮箱剩余寿命预测模型，以全生命周期振动信号为核心数据源，通过“数据采集—健康指标（HI）构建—退化轨迹建模—RUL 预测—性能评估”流程，依托四大核心模块实现精准预估^[7]。数据采集模块获取齿轮箱从正常到失效的完整振动数据；HI 构建模块从信号中提取量化退化状态的指标；退化轨迹建模模块利用深度学习捕捉退化的非线性、非平稳特性及时序规律；RUL 预测模块结合故障阈值完成寿命定量预测；性能评

估模块通过量化指标为模型优化提供依据。该框架优势在于实现退化状态量化，依托深度学习精准捕捉退化轨迹，适用于多工况场景。

（二）健康指标的构建与评估

健康指标是表征齿轮箱退化状态的核心参数，其质量直接决定剩余寿命预测精度，需满足三大核心要求。单调性、趋势性、区分度^[8]。文章采用多维度特征融合法构建指标，从全生命周期振动信号中提取时域、频域、时频域多维度原始特征；经格拉布斯准则剔除异常值、Z-score 标准化消除量纲差异、PCA 结合 LLE 降维，得到低维高相关特征子集；通过随机森林计算特征重要性权重并加权求和得到初始指标，经滑动平均平滑消除波动后获最终序列^[9]。评估采用单调性（M，Spearman 相关系数，[-1,1]，越近 ±1 越好）、趋势性（T，线性拟合优度，[0,1]，越近 1 越好）、区分度（D，类间 / 类内距离比，值越大越好）量化。

（三）基于序列学习的退化轨迹建模

齿轮箱退化过程具有复杂的非线性、非平稳时序特性，传统时序建模方法（如 ARIMA、灰色预测模型）难以精准捕捉其退化规律^[10]。基于序列学习的深度学习模型擅长时序依赖建模，可有效捕捉健康指标序列的非线性退化特征，为剩余寿命预测提供可靠支撑，故本文采用 GRU 与 Transformer 混合模型建模退化轨迹。GRU 可捕捉时序序列短期依赖，且结构简化、计算复杂度低；Transformer 基于自注意力机制，能捕捉长期依赖，适配长序列建模。流程上，通过滑动窗口划分健康指标序列得到输入输出样本对，划分训练 / 验证集后，将输入序列输入 GRU 获取短期退化特征向量，再输入 Transformer 编码器捕捉长期依赖并融合特征，实现退化轨迹精准建模。训练中采用 AdamW 优化算法、学习率策略提升收敛速度，结合 dropout、标签平滑及早停策略避免过拟合，保障模型精度与稳定性。

（四）RUL 预测模型构建与训练

RUL 预测模型以退化轨迹建模模块输出的融合特征向量为输入，结合齿轮箱故障阈值实现剩余寿命定量预测。文章采用全连接神经网络结合注意力机制构建该模型，以提升预测精度。采用统计方法结合专家经验，通过分析多个齿轮箱全生命周期健康指标序列，选取失效时刻指标值作为初始阈值，经专家修正后确定合理阈值，健康指标达该阈值时判定齿轮箱失效，剩余寿命为 0；融合特征向量先输入注意力层，通过计算各时刻健康指标注意力权重突出关键退化特征，再将其输出输入全连接层进行维度转换与非线性映射，输出剩余寿命预测值；以均方根误差（RMSE）为损失函数，用于衡量预测值与真实值的偏差，采用 AdamW 优化算法优化参数，调节学习率、批次大小等超参数提升收敛速度与精度；采用迁移学习，将某工况下训练好的模型迁移至其他工况，通过微调部分参数适应不同工况退化特性，减少新工况样本需求并降低训练成本。

（五）模型性能评估指标

为全面评估剩余寿命预测模型性能，选取 RMSE、MAE、MAPE、R² 为核心评估指标，引入预测稳定性指标衡量可靠性。RMSE 反映均方偏差、MAE 抗异常值干扰、MAPE 表征相对误

差，三者取值越小精度越高； R^2 衡量退化轨迹拟合度，越接近 1 效果越好，稳定性指标标准差越小则预测越平稳。实验采用不同工况下齿轮箱全生命周期数据集，通过对比指标验证模型优越性，同时分析其在早、中、晚期退化阶段的预测精度，明确适用范围与优化方向。

三、故障诊断与剩余寿命预测的融合模型研究

（一）融合的必要性与挑战

故障诊断与剩余寿命预测是风电机组齿轮箱 PHM 的核心环节，二者关联紧密。诊断可为预测提供初始状态、故障类型与程度等依据，预测可通过寿命变化趋势反哺诊断，提升其前瞻性与准确性。但现有研究多将二者视为独立任务，忽略关联信息导致模型性能受限，因此开展融合研究具有重要理论与工程价值。融合研究面临三大核心挑战，诊断多为分类数据、预测多为时序数据，格式与特征维度差异显著，异构数据融合是模型构建关键；诊断标签为故障类型与程度、预测为连续寿命值，合理损失函数设计是联合训练核心；需兼顾分类与回归精度，易导致训练难度增加、泛化能力下降，模型结构简化是优化重点。

（二）多任务学习融合框架设计

文章基于多任务学习（MTL）设计故障诊断与剩余寿命预测融合框架，核心含数据输入、共享特征提取、特定任务（故障诊断 / 剩余寿命预测）及输出四层。数据输入层转换振动信号（故障诊断）与健康指标序列（剩余寿命预测）为统一格式；共享特征提取层采用 CNN+Transformer 混合模型，提取异构数据共享特征并挖掘关联信息；特定任务层并行处理：故障诊断层通过

全连接层 + Softmax 输出故障类型与程度，剩余寿命预测层通过 GRU+ 全连接层输出预测值；输出层经注意力机制加权及专家经验修正，输出齿轮箱综合健康状态评估结果。

（三）融合模型的联合训练策略

融合模型联合训练的核心是解决标签不一致、任务权重不平衡问题，采用加权联合训练与交替训练结合的策略。加权联合训练，总损失函数为故障诊断的交叉熵损失与剩余寿命预测的均方误差损失的加权和，权重系数依据验证集性能自适应调整，保障两任务性能均衡；交替训练，先单任务训练两子模型获取初始化参数（避免初期训练不稳定），再基于该参数进行加权联合训练，结合自适应学习率提升收敛速度；防过拟合措施，引入 dropout 正则化、数据增强（高斯白噪声、平移、翻转等）提升泛化能力，采用早停策略保存最优参数。

四、结束语

本文围绕风电机组齿轮箱的故障诊断与剩余寿命预测两大核心问题，系统性地开展了基于振动信号与深度学习的研究工作，并取得了一系列有价值的成果。

在故障诊断方面，本文构建了从数据采集、预处理到特征提取与分类的完整技术框架。在剩余寿命预测方面，本文提出了“健康指标构建—退化轨迹建模—RUL 预测”的系统性解决方案。文章所提出的方法体系为风电机组齿轮箱的智能运维提供了有效的技术途径，对推动风电行业的智能化、数字化转型具有积极的促进作用。

参考文献

- [1] 陈子根. 风电机组齿轮箱故障诊断方法研究 [J]. 消费导刊, 2018(45): 155.
- [2] 唐明珠, 黎涛, 谭欣星, 等. 基于 ICSVM 的风电机组齿轮箱故障诊断 [J]. 计算机工程与应用, 2016, 52(14): 232–236. DOI: 10.3778/j.issn.1002-8331.1409-0122.
- [3] 王一宁, 甄成刚, 韩瑶瑶. 基于 AFSA-PSO-LSSVM 的风电机组齿轮箱故障诊断 [J]. 郑州大学学报 (理学版), 2022, 54(3): 81–87. DOI: 10.13705/j.issn.1671-6841.2021286.
- [4] 孙亚飞, 渠叶君. 基于数字孪生的风电机组齿轮箱故障诊断方法研究 [J]. 科技资讯, 2025, 23(1): 102–104. DOI: 10.16661/j.cnki.1672-3791.2404-5042-7653.
- [5] 王一宁, 甄成刚, 韩瑶瑶. 基于 AFSA-PSO-LSSVM 的风电机组齿轮箱故障诊断 [C]//CCF 第 36 届中国计算机应用大会论文集. 2021: 81–87.
- [6] 李辉, 李宣, 贾嵘, 等. 基于 EWT-OPRCMDE-ELM 的风电机组齿轮箱故障诊断研究 [J]. 自动化仪表, 2021, 42(11): 12–19. DOI: 10.16086/j.cnki.issn1000-0380.2021010028.
- [7] 高宏伟, 李新成, 何晓宁, 等. 基于希尔伯特变换的风电机组齿轮箱故障诊断方法研究 [J]. 机床与液压, 2024, 52(9): 215–220. DOI: 10.3969/j.issn.1001-3881.2024.09.032.
- [8] 王璞, 孙洁, 张怡. 基于 LSTM-SVM 的风电机组齿轮箱故障诊断 [J]. 机床与液压, 2023, 51(16): 211–214. DOI: 10.3969/j.issn.1001-3881.2023.16.031.
- [9] 丁硕, 常晓恒, 巫庆辉, 等. 基于 LVQ 神经网络风电机组齿轮箱故障诊断研究 [J]. 现代电子技术, 2014(10): 150–152. DOI: 10.3969/j.issn.1004-373X.2014.10.043.
- [10] 桂斌斌, 林国汉, 谢雅, 等. 基于 PSO-BP 的风电机组齿轮箱故障诊断 [J]. 湖南工程学院学报 (自然科学版), 2019, 29(3): 21–25. DOI: 10.3969/j.issn.1671-119X.2019.03.005.